

基于自监督特征提取的机械异常声音检测

薛英杰¹, 陈颀¹, 周松斌^{2*}, 刘忆森², 韩威²

¹昆明理工大学信息工程与自动化学院, 云南 昆明 650500;

²广东省科学院智能制造研究所, 广东省现代控制技术重点实验室, 广东 广州 510070

摘要 基于声音诊断的机械设备异常状态检测在工业自动化领域具有重要意义。当前, 无监督机械设备异常声音检测主要基于人工构造算法提取声音信号特征, 再以此特征进一步进行异常检测, 人工提取方法存在人为因素影响较大、通用性不强等问题。针对这些问题, 提出一种自监督特征提取新方法, 并将提取的特征输入自编码器(AE)进行机械设备异常声音检测。该方法首先将声音样本转换为时频谱图, 采用设备正常声音的时频谱图作为训练样本, 然后使用正常时频谱图和人为构造异常时频谱图构建自监督特征提取器(SSFE), 以 SSFE 提取的正常样本特征训练 AE, 实现无监督机械设备异常声音识别。使用 MIMII 公开数据集进行实验, 结果表明所提方法能够自适应提取滑轨、阀门、水泵和风扇等 4 种机械设备的声音特征, 最终获得的平均曲线下面积(AUC)检测结果为 88.5%, 相较于线性声谱图、对数梅尔谱、梅尔频率倒谱系数等人工特征提取方法的结果有显著提升。

关键词 机器视觉; 自监督学习; 无监督学习; 自编码器; 异常检测

中图分类号 TP391

文献标志码 A

DOI: 10.3788/LOP202259.1215013

Mechanical Abnormal Sound Detection Based on Self-Supervised Feature Extraction

Xue Yingjie¹, Chen Qi¹, Zhou Songbin^{2*}, Liu Yisen², Han Wei²

¹Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, Yunnan, China;

²Institute of Intelligent Manufacturing, Guangdong Academy of Sciences, Guangdong Key Laboratory of Modern Control Technology, Guangzhou 510070, Guangdong, China

Abstract Abnormal state detection of mechanical equipment based on acoustic diagnosis is of great significance in the field of industrial automation. At present, unsupervised abnormal sound detection of mechanical equipment is mainly based on artificial construction algorithms to extract sound signal features, and then use these features for further anomaly detection, which is greatly influenced by the human factors and the lack of universality of the artificial extraction method. To solve these problems, a new feature extraction method based on self-supervised learning is proposed, and the feature is input into the autoencoder (AE) for abnormal sound detection of mechanical equipment. In this method, the sound sample is firstly converted into a time-frequency spectrum, and the time-frequency spectrum of the normal equipment is used as the training sample, then the self-supervised feature extractor (SSFE) is constructed by using the normal time-frequency spectrum and the artificially constructed abnormal time-frequency spectrum. AE is trained by the features of normal samples extracted by SSFE to realize abnormal sound

收稿日期: 2021-07-19; 修回日期: 2021-08-09; 录用日期: 2021-08-19

基金项目: 国家重点研发计划(2019YFB1804204)、广东省重点领域研发计划(2019B010154002)、广东省自然科学基金(2020A1515010768)

通信作者: *18235194164@163.com

recognition of the unsupervised mechanical equipment. Experiments are carried out with MIMII open data set, and the results show that the proposed method can adaptively extract the sound features of four kinds of mechanical equipment, including fans, pumps, sliders and valves. The average area under curve (AUC) result obtained by the proposed method is 88.5%, which is significantly improved compared with those of the artificial feature extraction methods such as linear sonogram, logarithmic Mel spectrum, and Mel-frequency cepstral coefficients.

Key words machine vision; self-supervised learning; unsupervised learning; autoencoder; anomaly detection

1 引言

随着工业生产自动化的迅速发展,工厂中机械设备的正常运行对工业生产有着重要的作用,因此对机械设备的异常诊断研究有重要意义。目前基于振动信号的机械设备异常检测已被广泛应用。声音信号与振动信号类似,是反映设备运行状态的重要信息来源,并且声音信号具有采集方便、非接触测量、处理速度快等优点^[1]。机械设备异常声音是指设备处于异常状态运行时发出的声音,通过对机械设备运行声音识别来检测设备运行状态^[2-4],具有广泛的应用前景和重要的研究意义。龙磊等^[2]针对列车轴承轨边声学检测,提出了使用多普勒畸变对声音信号进行校正,并采用核特征矩阵联合近似对角化的方法提取校正后的声音信号特征,最后使用支持向量机(SVM)进行故障诊断。李春雷等^[3]采集了发电机正常状态声音和其他3种异常状态声音,将声音信号在时域和频域进行分解后得到的能量值、均方差值和峭度值作为声音特征,最后通过有监督学习的方式训练反向传播(BP)神经网络达到检测发电机状态的目的。上述方法具有较高的准确率,但需要对异常情况有明确的定义并且训练过程中需要大量异常声音样本。

然而现实工厂机械设备故障率低、故障种类多且操作环境相对复杂,难以收集到多类型、多工况的真实异常声音信号。无监督异常检测训练过程只需正常样本即可完成,因此无监督异常检测方法在工业声学检测中显得尤为重要。目前无监督异常检测主要有基于数据重构的方法^[5-8]、基于概率分布^[9-11]的方法和基于分类器的方法^[12-13];基于数据重构的方法是将原始样本进行压缩,并根据压缩后的数据尽可能地重构原始样本,使用重构误差作为异常分数。例如自编码器(AE),赵光权等^[5]使用轴承正常振动信号训练AE模型,该模型能够以较小的误差重构测试正常样本,而异常样本重构误差则较大,以重构误差作为异常分数,达到检测轴承健康状态的目的;基于概率分布的方法是假设样本特征符合正态分布,如果样本数据点在整体分布上的概率密度值较小,即为异常。例

如高斯混合模型,Qu等^[11]提出了使用高斯混合模型对高光谱数据进行异常检测;基于分类器的方法是在特征空间中学习正常样本周围的边界。例如单类支持向量机(OC-SVM),陈志全等^[12]提出OC-SVM异常环境声音检测算法,仅使用正常环境声音训练一个OC-SVM来判断被测声音是否为正常环境声音。上述方法已被证明具有良好的实用性。

同时由于工业场景较为复杂,工业声学信号存在高维度、非线性、多项混叠等问题,因此在进行声学异常检测时需要先对工业声学时频信号进行进一步的特征提取,才能进入异常检测器进行异常识别。提取声音信号特征是无监督机械声音异常检测的难点之一。目前常用的声学信号特征提取方法包括线性声谱图(line spectrum)^[14]、对数梅尔谱(log-Mel)^[8]、梅尔频率倒谱系数(MFCCs)^[15]、谐波分量(hpss-h)和冲击分量(hpss-p)^[16]等。吴侃^[14]提取了离心泵运行声音的line spectrum特征,然后根据此特征进行设备异常检测。2020DCASE^[8]比赛任务2为无监督机器异常声音检测,基线系统首先提取机械设备正常运行声音的log-Mel特征,并用提取出的特征训练一个AE,并将重构误差作为判别标准。Truong等^[15]提取了机械设备正常运行声音的MFCCs特征,同样也使用提取的特征训练AE,实现无监督机械设备异常声音检测。然而这些特征提取方法需要人为指定超参数,人为经验影响较大,且针对不同类型机械设备声音信号,特征提取效果往往通用性不强。而自监督特征提取是通过设置附属任务来学习对下游任务有用的特征,已广泛应用于图像领域^[17-19]。Gidaris等^[17]将图像进行不同角度的旋转,将识别图像旋转的角度作为附属任务来提取图像深度特征。上述方法已被证明在图像异常检测中具有良好的实用性,但自监督学习在声学异常检测中暂未见报道。针对人工提取声音信号特征存在人为影响较大、通用性不强等问题,本文提出一种自监督特征提取新方法,由于提取的特征仍为高维特征,因此将此特征输入AE进行机械设备异常声音检测。

本文方法首先将声音样本转换为时频谱图,并采用随机增强减弱、添加粉噪声等方法生成异常时频谱图,然后使用正常时频谱图与人造异常时频谱图训练一个卷积二分类网络从而构建自监督特征提取器(SSFE)。最后使用SSFE提取的正常样本特征训练一个AE,基于自编码重构误差,实现无监督机械设备异常声音检测。通过对MIMII公开数据集滑轨、阀门、水泵和风扇等4种机械设备进行异常声音检测证明了该方法的有效性。

2 基于自监督特征提取和AE的机械异常声音检测方法

2.1 自监督特征提取

自监督学习是指人为构造监督信息,通过这种构造的监督信息对网络模型进行训练完成附属任

务,从而学习到对下游任务,即异常检测任务有价值的特征^[20]。工厂中机械设备异常状态种类多,出现概率低,异常声音样本难以采集,训练样本一般只包含正常声音样本。为提取设备声音特征,使用正常样本时频谱生成异常样本时频谱图,并使用正常样本时频谱图和生成的异常样本时频谱图构建SSFE,即训练一个卷积神经网络(CNN)二分类网络。将该网络用于分类的中间特征作为SSFE的输出,即提取的声音信号特征,特征提取过程如图1所示。该网络通过学习区分正常样本时频谱图与人造异常样本时频谱图的附属任务,实现正常样本深度特征提取,进而完成真实异常检测的下游任务。传统CNN计算量大、参数多,对计算机要求较高,考虑到下一步在工厂移动端的使用,因此本文采用轻量级卷积网络MoblienetV2。

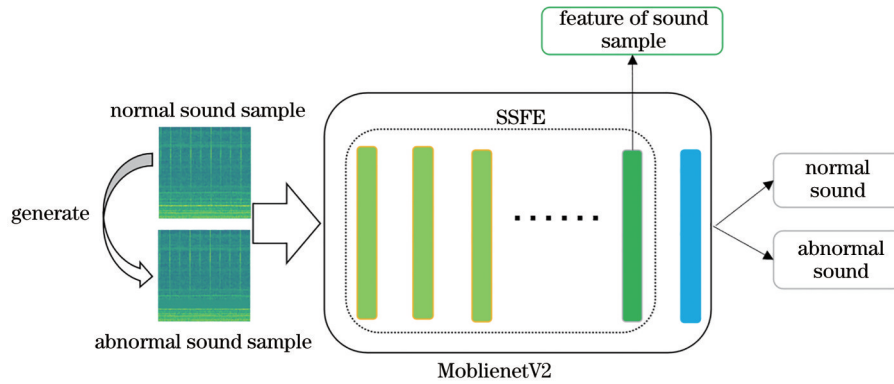


图1 自监督特征提取过程

Fig. 1 Process of self-supervised feature extraction

本文主要通过添加粉噪声和随机增强减弱两种方法构造异常声音数据。粉噪声是指在一定的范围内音频数据具有相同的能量,例如40 Hz到80 Hz频段内能量与10 kHz到20 kHz能量是相同的,粉噪声的能量从低频向高频不断衰减,如图2所示为粉噪声的频谱图。由图可知,粉噪声的频率分




图2 粉噪声功率谱

Fig. 2 Power spectrum of pink noise

量主要分布在中低频段。许多机械设备运行声音频率分量也主要分布在中低频段,加入粉噪声能够有效干扰这些设备运行声音,因此向正常声音样本加入粉噪声获得异常样本。使用Matlab生成粉噪声过程如图3所示。

此外,当机械设备出现异常时,一些频率段幅值会发生明显变化,因此对正常声音样本时频谱图进行幅值变化生成异常样本时频谱图,幅值变化公式为

$$A_{f_i} = \alpha A_{f_i}, f_i \in (f_1, f_2, f_3, \dots, f_n), \quad (1)$$

$$A_{f_j} = \beta A_{f_j}, f_j \in (f_1, f_2, f_3, \dots, f_n), \quad (2)$$

式中: A_{f_i} 表示时频谱图中所有时间段频率为 f_i 的幅值; $\alpha \in [0, 1]$; $\beta \in (1, 10]$;随机选 n 个频率段幅值进行变化, $n \in [1, 10]$ 。

构造异常样本后,使用正常样本时频谱图与异常时频谱图训练MoblienetV2网络,并以此网络池化层的输出作为SSFE提取的特征。MoblienetV2^[21-22]




图 3 Matlab生成粉噪声过程

Fig. 3 Process of pink noise generation by Matlab

网络使用了深度可分离卷积(DSC),DSC可分解为深度卷积和点卷积两个部分,也就是说,DSC操作可分为两步,首先对输入样本的每个通道使用深度卷积核进行计算,然后使用点卷积核进行计算后输出

结果,过程如图 4 所示。DSC的作用为加快网络运行速度和减少网络参数。

标准卷积与DSC计算量对比如下:假设卷积层输入特征为 f_i ,大小为 $D_i * D_i * M$,输出特征为 f_o ,大小为 $D_o * D_o * N$ 。其中, D_i 和 D_o 分别表示 f_i 和 f_o 的长宽, M 和 N 分别表示 f_i 和 f_o 的通道数。当使用标准卷积进行计算时,标准卷积核大小为 $D_k * D_k * M * N$,其中 D_k 为卷积核的长宽,直接对 f_i 进行卷积计算得到 f_o ,计算次数为 $D_k * D_k * M * N * D_i * D_i$;当使用DSC进行计算时,首先使用 M 个大小为 $D_k * D_k * 1$ 的深度卷积核在 f_i 的每个通道进行计算,得到中间特征 f_m ,大小为 $D_k * D_k * M$,此过程的计算次数为 $D_k * D_k * M * D_i * D_i$;然后使用 N 个大小为 $1 * 1 * M$ 点卷积核对上一步结果继续进行计算,得到输出特征 f_o ,此过程计算次数为 $M * N * D_i * D_i$;最终DSC计算次数为这两个过程计算次数之和: $D_k * D_k * M * D_i * D_i + M * N * D_i * D_i$,与标准卷积计算次数比为 $1/N + 1/D_k^2$ 。MoblienetV2网络中采用 $3 * 3$ 的卷积核,计算次数大约仅为标准卷积的 $1/9$,大大减少了计算量。

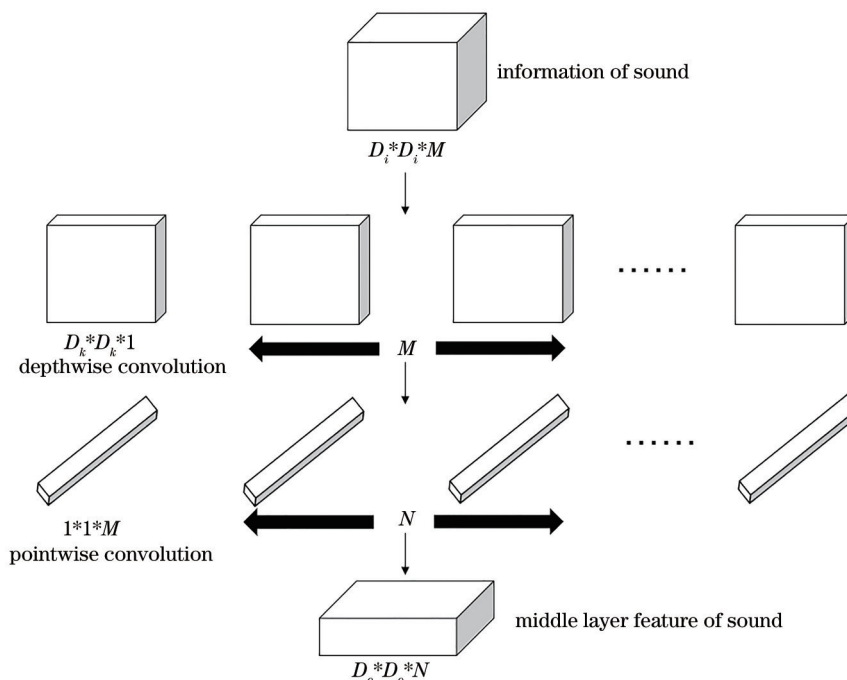


图 4 深度可分离卷积流程图

Fig. 4 Flowchart of deeply separable convolution

除此之外, MoblienetV2 网络还加入了 expansion 层和 projection 层,都采用 conv(1, 1) 的网络结构, expansion 层的目的是将输入数据从低维空间映射到高维空间, projection 层的目的与扩展层相反,是将输入数据从高维空间映射到低维空

间。 expansion 层、DSC 层、projection 层共同组成了 Bottleneck 模块, Bottleneck 模块结构如图 5 所示,其中 Relu6 表示限制最大输出值为 6 的激活函数。

MoblienetV2 网络结构如表 1 所示。

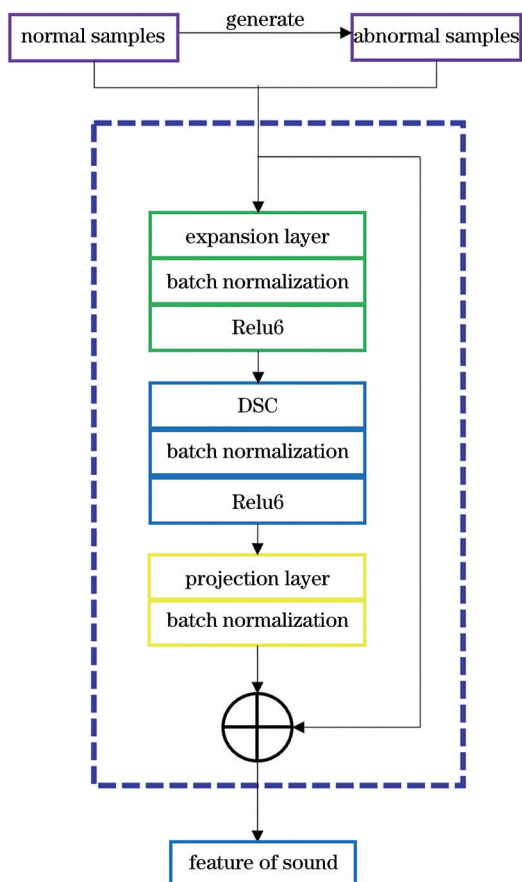


图 5 Bottleneck 模块结构

Fig. 5 Structure of Bottleneck module

表 1 MoblienetV2 网络结构

Table 1 Network structure of MoblienetV2

Operator	Expansion factor	Channel	Repeated times	Stride
Conv2D	—	16	1	2
Bottleneck	1	8	1	1
Bottleneck	6	16	2	2
Bottleneck	6	16	3	2
Bottleneck	6	32	4	2
Bottleneck	6	48	3	1
Bottleneck	6	80	3	2
Bottleneck	6	160	1	1
Conv2D	—	1280	1	1
Avg pool	—	1280	1	—

2.2 自编码异常检测器

AE 是一对相互连接的子网络^[23], 包括编码器和解码器。编码器中的全连接层将输入数据进行压缩, 得到隐藏层, 解码器中的全连接层将隐藏层解压, 尽可能地再现生成原始输入。AE 的编码过程可描述为

$$h_1 = \sigma_e(w_1 x + b_1), \quad (3)$$

解码过程可描述为

$$y = \sigma_d(w_2 h_1 + b_2), \quad (4)$$

式中: x 表示 AE 的输入; h_1 表示隐藏层; y 表示解码器重构数据, 即 AE 的输出; σ_e, σ_d 表示非线性变换; w_1, w_2, b_1 和 b_2 表示神经网络的参数, 通过优化器最小化 x 和 y 之间的重构误差来获得。AE 结构如图 6 所示。重构误差公式为

$$\epsilon = \sum_{i=0}^n (x_i - y_i)^2 / n, \quad (5)$$

式中: x_i 表示原始输入数据; y_i 表示生成器生成数据; n 表示数据长度。

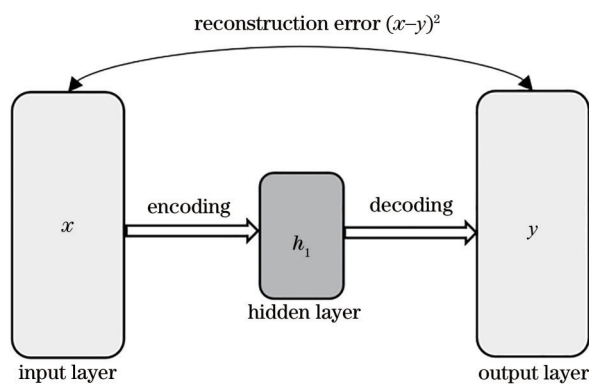


图 6 AE 结构图

Fig. 6 Structure diagram of AE

利用 AE 进行无监督异常检测时, 首先使用正常数据训练 AE, 让其编码解码网络学得正常数据的表达方式, 测试过程中从而能对正常数据以较小的误差重构, 而重构异常数据则会产生较大的误差。因此可将重构误差作为检测标准, 进行异常检测。

2.3 基于自监督特征提取和 AE 的机械设备异常声音检测

对机械设备进行异常声音检测时, 首先生成异常样本时频谱图, 然后使用正常样本时频谱图和生成的异常样本时频谱图训练 MoblienetV2 网络从而构建 SSFE, 然后使用 SSFE 提取训练集样本特征, 最后使用提取的特征训练 AE。检测流程图如图 7 所示, 步骤如下:

- 1) 将训练集(只包含机械设备正常状态时运行声音)和测试集(包含机械设备正常状态和异常状态运行声音)进行分帧、加窗;
- 2) 对所有样本进行短时傅里叶变换(STFT)得到时频谱图;
- 3) 使用训练集正常样本时频谱图生成异常样本时频谱图;

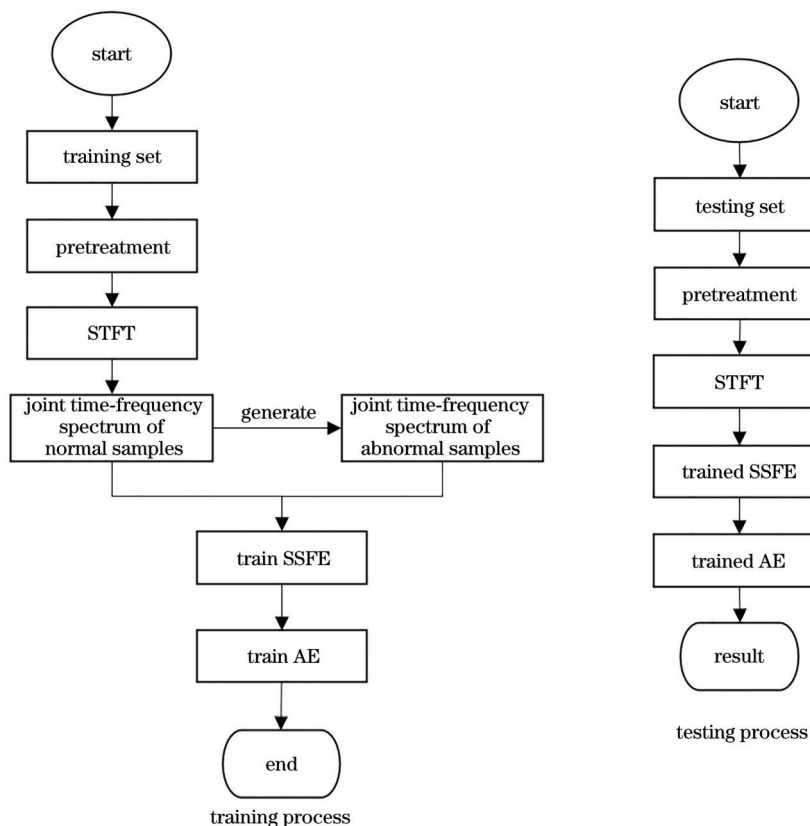


图 7 机械设备异常声音检测流程图

Fig. 7 Flowchart of abnormal sound detection for mechanical equipment

4) 使用训练集正常样本时频谱图和生成的异常样本时频谱图训练 MoblienetV2 网络从而构建 SSFE;

5) 使用 SSFE 提取训练集正常样本时频谱图的特征, 并以此训练一个 AE 作为异常检测器;

6) 测试时, 首先将测试样本时频谱图输入 SSFE 进行特征提取, 然后使用训练好的 AE 进行机械设备异常声音检测。

3 实验结果与分析

3.1 实验数据

采用 MIMII 公开数据集进行实验验证^[24]。该数据集使用 TAMAGO-03 麦克风采集了滑轨、阀

门、水泵和风扇 4 种不同类型的机械设备声音, 采集的声音信号中包括目标机械设备的声音和真实工厂的背景噪声, 采样率为 16 K, 样本时长大约为 10 s。训练集只包含设备正常状态时运行声音, 测试集包含设备正常状态运行声音和各种异常状态运行声音, 滑轨异常状态包括钢轨损坏、皮带松动和缺少润滑油等, 阀门异常状态包括两种以上的污染, 水泵异常状态包括泄露和堵塞等, 风扇状态包括电压发生变化、叶片污染和扇叶转动不平衡等。声音数据集划分如表 2 所示。使用 librosa 库中的 stft 函数获取声音时频谱, 测试集正常声音样本和异常声音样本时频谱如图 8 所示。

本文使用曲线下面积(AUC)作为实验评价指

表 2 4 种机械设备声音数据划分

Table 2 Data partition of four kinds of machine sound

Type	Number of samples in training sets	Number of normal samples in testing sets	Number of abnormal samples in testing sets
Slider	2804	400	890
Valve	3291	400	479
Pump	3349	400	456
Fan	3675	400	1475

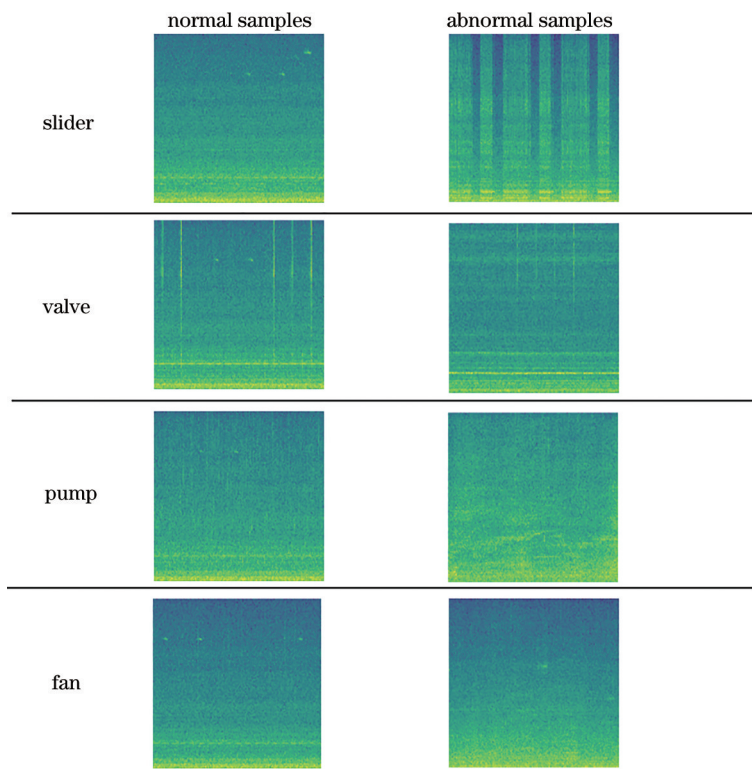


图 8 测试集正常声音样本和异常声音样本时频谱图

Fig. 8 Time-frequency spectra of test sets of normal sound samples and abnormal sound samples

标, AUC 是异常检测中最为常用的评价指标之一^[25]。AUC 计算公式如下:

$$D_{AUC} = \frac{1}{N_- N_+} \sum_{i=1}^{N_-} \sum_{j=1}^{N_+} H(y_j^+ - y_i^-), \quad (6)$$

式中: $H(a)$ 为阈值函数, 当 $a > 0$ 时, $H(a) = 1$, 当 $a \leq 0$ 时, $H(a) = 0$; y_j^+ 、 y_i^- 分别表示异常样本检测结果和正常样本检测结果; N_+ 、 N_- 分别表示异常样本和正常样本的个数。

3.2 实验设置

实验程序运行平台为 Linux 操作系统, TITANV

显卡, 显存为 12 G, 基于 keras 搭建网络模型。网络采用 Adam 优化器进行训练, 学习率设置为 0.0001。stft 使用汉明窗, 窗口长度为 512, 滑动长度为 256。

3.3 实验研究与分析

通过添加粉噪声和随机增强减弱生成的异常声音样本时频谱图如图 9 所示。

将本文方法在上述公开数据集 4 种机械设备声音数据中进行评估。训练过程中, 利用区分正常样本时频谱图和生成的异常样本时频谱图附属任务, 约束 SSFE 提取出有效特征。对测试样本原始特征(时频

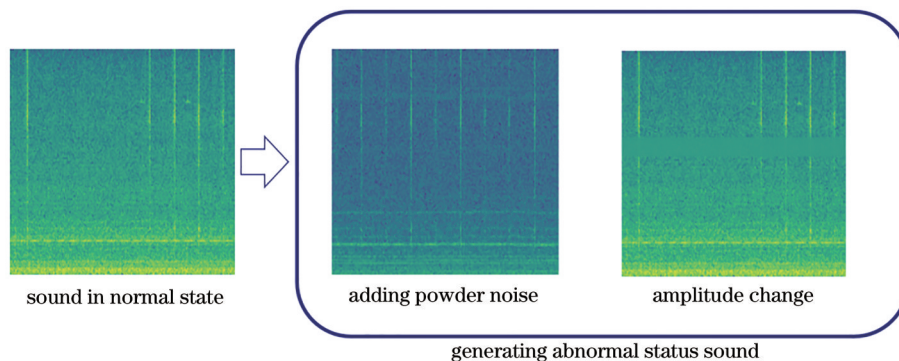


图 9 生成异常样本时频谱图

Fig. 9 Time-frequency spectra of generating abnormal samples

谱图)和进一步采用 SSFE 提取的特征利用 t-SNE^[26] 进行降维可视化,结果如图 10 和图 11 所示。对比两个图可知,直接使用原始特征难以区分正常样本与异常

常样本,而 SSFE 能够学习正常数据的深层次特征分布,从而使正常样本和异常样本呈现较好的聚类趋势,为下一步 AE 异常检测提供了更好的支持。

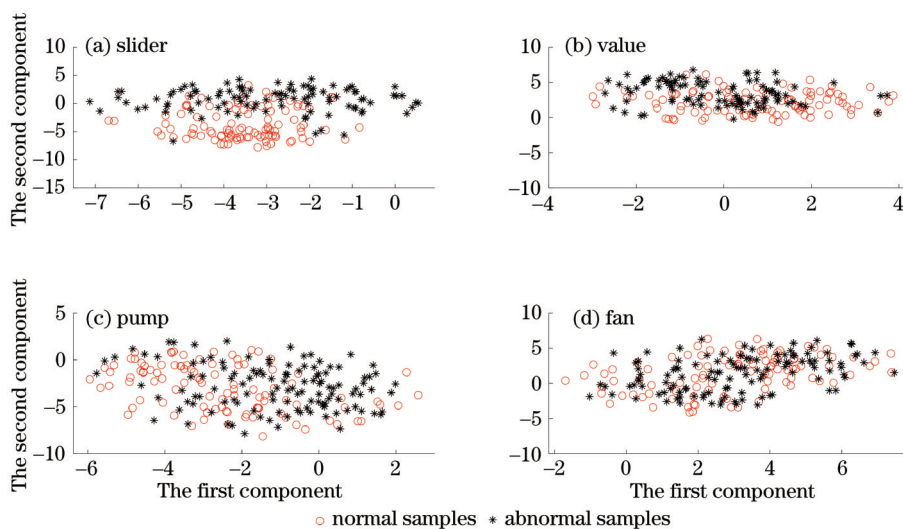


图 10 测试样本的原始时频特征可视化图

Fig. 10 Visualization of original time-frequency characteristics of test samples

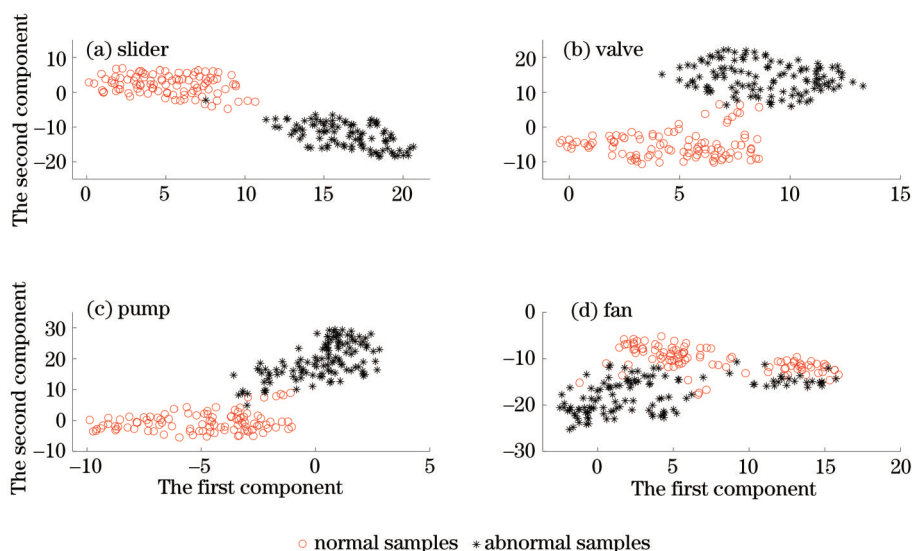


图 11 测试样本自监督提取特征可视化图

Fig. 11 Visualization of test sample self-supervised feature extraction

3.4 特征提取方法对比分析

为证明 SSFE 的有效性,将本文 SSFE 提取的特征与其他 5 种常用的人工构造算法提取的特征^[16] 进行对比,包括 line spectrum、log-Mel、MFCCs、hpss-h 和 hpss-p。在样本时频谱图基础上,采用不同的特征提取方法进行声学特征提取,然后使用 AE 进行异常检测,其异常检测 AUC 结果对比如图 12 所示。

由图 12 可知,相同条件下,当选用不同的人工

声音特征提取方法时,检测结果不同。人工声音特征提取方法具有一定的局限性,难以准确提取适用于异常检测的声音特征。在相同条件下,4 种类型的设备使用 SSFE 提取的特征取得最佳异常检测效果,比上述最优传统提取的特征检测结果分别高 3.7%、8.6%、8.4% 和 13.0%。证明 SSFE 能够提取更适用于异常检测的声音特征,并且通用性较强,适用于不同类型的机械设备。

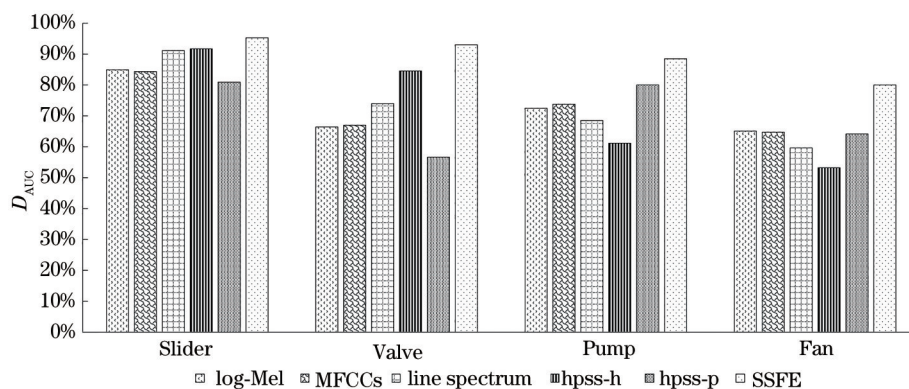


图 12 6 种特征提取方法的异常检测 AUC 结果

Fig. 12 AUC results of six feature extraction methods for anomaly detection

3.5 异常检测方法对比分析

除了 AE, 还使用其他 6 种常用的异常检测方法进行了实验, 包括单类支持向量机^[27](OCSVM)、孤立森林^[28](IF)、K 均值聚类法^[29](Kmeans)、高斯混

合模型^[11](GMM)、卷积自编码器^[30](CAE)和深度自编码高斯混合模型^[31](DAGMM), 实验全部使用 SSFE 提取的特征, AUC 结果如表 3 所示。

表 3 不同异常检测模型性能比较

Table 3 Performance comparison of different anomaly detection models

Model	Slider $D_{AUC} / \%$	Valve $D_{AUC} / \%$	Pump $D_{AUC} / \%$	Fan $D_{AUC} / \%$	Average $D_{AUC} / \%$
SSFE-IF	94.6	85.2	82.9	74.5	84.3
SSFE-Kmeans	93.8	82.7	80.2	73.7	82.6
SSFE-OCSVM	85.6	78.8	74.5	65.3	76.1
SSFE-GMM	94.5	89.9	87.6	76.8	87.2
SSFE-DAGMM	94.5	91.3	88.5	78.1	88.1
SSFE-CAE	94.8	91.2	89.0	78.2	88.3
SSFE-AE	95.0	92.7	88.2	78.0	88.5

由表 3 可知, 在相同的实验条件下, AE 异常检测器在 6 种机械设备数据集中都得到了较优的异常检测结果, 其平均 AUC 值比 IF、Kmeans、OCSVM、GMM 和 CAE 分别提高了 4.2、5.9、12.4、1.3、0.4、0.2 个百分点。本文所述 SSFE 得到的特征维度为 1280, 仍属于高维特征, AE 相较于其他异常检测器 (IF、Kmeans、OCSVM 和 GMM), 具有更好的高维特征处理能力。DAGMM 网络首先对输入特征进行降维处理, 然后通过密度估计进行异常检测, 相比于 GMM 检测结果有所提高。CAE 与 AE 有着相似的网络结构, 都由编码器和解码器组成, CAE 将 AE 的全连接层替换成卷积层, 检测结果也与 AE 相近。

4 结 论

提出一种自监督特征提取新方法, 并将此特征输入 AE 进行机械设备异常声音检测。首先通过添加粉噪声和随机增强减弱人为生成异常声音样本时频谱图, 然后使用正常声音样本时频谱图和生成

的异常样本时频谱图训练卷积二分类网络从而构建 SSFE, 最后使用 SSFE 提取出的正常样本特征训练 AE, 从而实现机械设备异常声音检测。实验证明对于不同类型的机械设备, 不同的人工声学特征提取方法, 异常检测效果存在差异, 通用性不强; SSFE 提取的特征异常检测结果优于人工提取的特征, SSFE 通过附属的正常与人造异常分类任务, 学习正常样本分布, 所提取特征对后续异常检测器适应性更好, 并且通用性较强, 可适用于不同类型的机械设备; 使用 SSFE 提取的特征进行异常检测时, AE 的检测结果优于其他几种常用的无监督异常检测方法。提出方法在机械设备状态监测领域具有广泛的应用前景。

参 考 文 献

- [1] 瞿金秀, 杨飞宇, 张周锁, 等. 基于声音信号的结构损伤识别方法[J]. 振动·测试与诊断, 2014, 34(4): 638-643, 774.

- Qu J X, Yang F Y, Zhang Z S, et al. Identification method for structural damage based on acoustic signal [J]. *Journal of Vibration, Measurement & Diagnosis*, 2014, 34(4): 638-643, 774.
- [2] 龙磊, 何兵, 刘方, 等. 基于 KJADE 的列车轴承轨边声学诊断方法研究[J]. *振动·测试与诊断*, 2020, 40(4): 781-787, 828.
- Long L, He B, Liu F, et al. Fault diagnosis of locomotive bearings using wayside acoustic signals based on KJADE[J]. *Journal of Vibration, Measurement & Diagnosis*, 2020, 40(4): 781-787, 828.
- [3] 李春雷, 董志学, 王新杰. 发电机声音检测与故障诊断研究[J]. *内蒙古工业大学学报(自然科学版)*, 2015, 34(3): 201-208.
- Li C L, Dong Z X, Wang X J. Based on the generator sound detection and fault diagnosis research [J]. *Journal of Inner Mongolia University of Technology (Natural Science Edition)*, 2015, 34(3): 201-208.
- [4] Jeon S, Shin J W, Lee Y J, et al. Empirical study of drone sound detection in real-life environment with deep neural networks[C]//2017 25th European Signal Processing Conference (EUSIPCO), August 28-September 2, 2017, Kos, Greece. New York: IEEE Press, 2017: 1858-1862.
- [5] 赵光权, 刘小勇, 姜泽东, 等. 基于深度学习的轴承健康因子无监督构建方法[J]. *仪器仪表学报*, 2018, 39(6): 82-88.
- Zhao G Q, Liu X Y, Jiang Z D, et al. Unsupervised health indicator of bearing based on deep learning[J]. *Chinese Journal of Scientific Instrument*, 2018, 39(6): 82-88.
- [6] 尹爱军, 王昱, 戴宗贤, 等. 基于变分自编码器的轴承健康状态评估[J]. *振动·测试与诊断*, 2020, 40(5): 1011-1016, 1030.
- Yin A J, Wang Y, Dai Z X, et al. Evaluation method of bearing health state based on variational auto-encoder[J]. *Journal of Vibration, Measurement & Diagnosis*, 2020, 40(5): 1011-1016, 1030.
- [7] Khalilian S, Hallaj Y, Balouchestani A, et al. PCB defect detection using denoising convolutional autoencoders[C]//2020 International Conference on Machine Vision and Image Processing (MVIP), February 18-20, 2020, Iran. New York: IEEE Press, 2020: 19945169.
- [8] Koizumi Y, Kawaguchi Y, Imoto K, et al. Description and discussion on DCASE2020 challenge Task2: unsupervised anomalous sound detection for machine condition monitoring[C]//Proceedings of 5th the Workshop on Detection and Classification of Acoustic Scenes and Events 2020 (DCASE 2020), November 2-4, 2020, Tokyo, Japan. [S.l.: s. n.], 2020.
- [9] 于冰洁. 基于高斯模型的异常检测算法[D]. 徐州: 中国矿业大学, 2017.
- Yu B J. Anomaly detection algorithm based on Gaussian model[D]. Xuzhou: China University of Mining and Technology, 2017.
- [10] 张弛, 孟庆浩, 井涛. 基于改进 GMM 和多特征融合的视频火焰检测算法[J]. *激光与光电子学进展*, 2021, 58(4): 0410006.
- Zhang C, Meng Q H, Jing T. Video flame detection algorithm based on improved GMM and multi-feature fusion[J]. *Laser & Optoelectronics Progress*, 2021, 58(4): 0410006.
- [11] Qu J H, Du Q, Li Y S, et al. Anomaly detection in hyperspectral imagery based on Gaussian mixture model[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 59(11): 9504-9517.
- [12] 陈志全, 杨骏, 乔树山. 基于单类支持向量机的异常声音检测[J]. *电子设计工程*, 2016, 24(23): 19-22.
- Chen Z Q, Yang J, Qiao S S. Abnormal sound detection based on one class support vector machine [J]. *Electronic Design Engineering*, 2016, 24(23): 19-22.
- [13] 李晨, 王布宏, 田继伟, 等. 基于 LSTM-OCSVM 的无人机传感器数据异常检测[J]. *小型微型计算机系统*, 2021, 42(4): 700-705.
- Li C, Wang B H, Tian J W, et al. Anomaly detection method for UAV sensor data based on LSTM-OCSVM[J]. *Journal of Chinese Computer Systems*, 2021, 42(4): 700-705.
- [14] 吴侃. 离心泵空化状态识别方法研究与实现[D]. 镇江: 江苏大学, 2019.
- Wu K. Research and implementation of cavitation state recognition method for centrifugal pump[D]. Zhenjiang: Jiangsu University, 2019.
- [15] van Truong H, Hieu N C, Giao Pham N, et al. Unsupervised detection of anomalous sound for machine condition monitoring using different auto-encoder methods[J]. *Journal of ICT Research and Applications*, 2021, 15(1): 41-55.
- [16] Bai J S, Chen C, Chen J F. Feature based fusion system for anomalous sounds monitoring[EB/OL]. [2021-02-03]. http://dcase.community/documents/challenge2020/technical_reports/DCASE2020_Bai_127_t2.pdf.

- [17] Gidaris S, Singh P, Komodakis N. Unsupervised representation learning by predicting image rotations [EB/OL]. (2018-03-21) [2021-02-01]. <https://arxiv.org/abs/1803.07728>.
- [18] 陆县委, 刘辉, 尚振宏. 基于自监督深度学习的 NVST 图像去噪[J]. 激光与光电子学进展, 2021, 58(6): 0610018.
Lu X W, Liu H, Shang Z H. NVST image denoising based on self-supervised deep learning[J]. Laser & Optoelectronics Progress, 2021, 58(6): 0610018.
- [19] 黄鸿, 彭超, 吴若愚, 等. 基于部分注释 CT 图像的自监督迁移学习肺结节分类[J]. 光学学报, 2020, 40(18): 1810003.
Huang H, Peng C, Wu R Y, et al. Self-supervised transfer learning of pulmonary nodule classification based on partially annotated CT images[J]. Acta Optica Sinica, 2020, 40(18): 1810003.
- [20] 代雨柔, 杨庆, 张风荔, 等. 基于自监督学习的社交网络用户轨迹预测模型[J]. 计算机应用, 2021, 41(9): 2545-2551.
Dai Y R, Yang Q, Zhang F L, et al. Trajectory prediction model of social network users based on self-supervised learning[J]. Journal of Computer Applications, 2021, 41(9): 2545-2551.
- [21] Sandler M, Howard A, Zhu M L, et al. MobileNetV2: inverted residuals and linear bottlenecks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 4510-4520.
- [22] Kuo H H, Xu J, Yu C T, et al. Screw defect detection system based on AI image recognition technology[C]//2020 International Symposium on Computer, Consumer and Control (IS3C), November 13-16, 2020, Taichung City, Taiwan, China. New York: IEEE Press, 2020: 493-496.
- [23] 梁凤勤, 高媛, 刘功银, 等. 基于 AutoEncoder 的油气管道控制系统异常状态监测方法[J]. 电子测量与仪器学报, 2019, 33(12): 10-18.
Liang F Q, Gao Y, Liu G Y, et al. Pipeline control system fault detection method based on Auto-Encoder[J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(12): 10-18.
- [24] Purohit H, Tanabe R, Ichige T, et al. MIMII dataset: sound dataset for malfunctioning industrial machine investigation and inspection[C]//Proceedings of the Detection and Classification of Acoustic Scenes and Events 2019 Workshop (DCASE2019), October 25-26, 2019, New York University, NY, USA. [S.l.: s.n.], 2019: 209-213.
- [25] Koizumi Y, Saito S, Uematsu H, et al. Unsupervised detection of anomalous sound based on deep learning and the Neyman-Pearson lemma[J]. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2019, 27(1): 212-224.
- [26] Laurens V D M, Hinton G. Visualizing data using t-SNE[J]. Journal of Machine Learning Research, 2008, 9: 2579-2605.
- [27] 毛前军, 梁致远, 刘冬华, 等. 基于单类支持向量机的冷水机组温度传感器故障检测[J]. 制冷学报, 2019, 40(5): 130-135, 142.
Mao Q J, Liang Z Y, Liu D H, et al. Fault detection of temperature sensor in chiller based on one-class support vector machine algorithm[J]. Journal of Refrigeration, 2019, 40(5): 130-135, 142.
- [28] 赵嫚, 李英娜, 李川, 等. 基于模糊聚类和孤立森林的用电数据异常检测[J]. 陕西理工大学学报(自然科学版), 2020, 36(4): 38-43.
Zhao M, Li Y N, Li C, et al. Anomaly detection of power consumption data based on fuzzy clustering and isolated forest[J]. Journal of Shaanxi University of Technology (Natural Science Edition), 2020, 36(4): 38-43.
- [29] 蒋华, 季丰, 王慧娇, 等. 改进 Kmeans 算法的海洋数据异常检测[J]. 计算机工程与设计, 2018, 39(10): 3132-3136.
Jiang H, Ji F, Wang H J, et al. Improved Kmeans algorithm for ocean data anomaly detection[J]. Computer Engineering and Design, 2018, 39(10): 3132-3136.
- [30] 于晓升, 许茗, 王莹, 等. 基于卷积变分自编码器的异常事件检测方法[J]. 仪器仪表学报, 2021, 42(5): 151-158.
Yu X S, Xu M, Wang Y, et al. Anomaly detection method based on convolutional variational auto-encoder[J]. Chinese Journal of Scientific Instrument, 2021, 42(5): 151-158.
- [31] Kabir M A, Luo X. Unsupervised learning for network flow based anomaly detection in the era of deep learning[C]//2020 IEEE Sixth International Conference on Big Data Computing Service and Applications, August 3-6, 2020, Oxford, UK. New York: IEEE Press, 2020: 165-168.